



面向工业互联网的语义编码传输方法及应用*

牛凯^{1,2,3}, 鲁延鹏^{1,2}, 董超^{1,2}

1. 北京邮电大学人工智能学院, 北京 100876
2. 泛网无线通信教育部重点实验室, 北京 100876
3. 鹏城实验室, 广东 深圳 518055

摘要: 通过将语义通信技术引入工业网络, 构建了一个面向工业互联网的语义编码传输系统。系统中设计了语义编解码器以提取信源中的语义信息, 相对于传统通信系统, 基于语义信息的通信有更高的信息压缩效率与更高的符号差错容忍能力。同时引入信源信道联合编解码器, 以信源信道联合编码的方式将语义信息转化为信道符号传输, 进一步提升系统对工业网络通信资源的利用效率。所有编解码器均构建在深度神经网络架构 Transformer 上, 确保了编解码器对语义信息的理解能力及系统的泛化能力。在工业药品生产场景中, 对该系统进行测试, 结果显示: 相较于传统通信方案, 该语义编码传输系统在图像重建质量和传输处理速度方面均有显著提升。且系统对下游任务的性能影响极小, 保证了工业生产中如缺陷检测等关键任务的准确性。

关键词: 工业互联网; 数据压缩与传输; 语义通信; 深度学习

中图分类号: TN929.5 **文献标志码:** A **文章编号:** 2097-0137(2025)01-0051-10

Semantic coding transmission method and application for industrial internet

NIU Kai^{1,2,3}, LU Yanpeng^{1,2}, DONG Chao^{1,2}

1. School of Artificial Intelligence, Beijing University of Posts and Telecommunications, Beijing 100876, China
2. The Key Laboratory of Universal Wireless Communications, Ministry of Education, Beijing 100876, China
3. Peng Cheng Laboratory, Shenzhen 518055, China

Abstract: The integration of semantic communication technology into industrial networks is proposed and a semantic coding transmission system for the industrial internet is established. Within this system, a semantic codec is developed to extract semantic information from the source. Compared with traditional communication systems, semantic-based communication offers higher information compression efficiency and greater symbol error tolerance. Furthermore, a co-codec for joint source-channel coding have been introduced, which enhances the utilization efficiency of industrial network communication resources through co-coding techniques. All codecs are built upon leading deep neural network architecture “Transformer”, ensuring their ability to comprehend semantic information and maintain network universality. The system has been tested in real-world scenarios within industrial drug production facilities, demonstrating significant improvements in image reconstruction quality and

* 收稿日期: 2024-06-18

录用日期: 2024-07-14

网络首发日期: 2024-10-08

基金项目: 国家自然科学基金(92067202)

作者简介: 牛凯(1976年生), 男; 研究方向: 信息论与极化码、智能信号处理;

E-mail: niukai@bupt.edu.cn

全文阅读



ZR20240204

transmission processing speed compared to traditional communication schemes. Additionally, minimal impact on downstream task performance ensures accuracy in critical tasks such as defect detection in industrial production processes.

Key words: industrial internet; data compression and transmission; semantic communications; deep learning

工业互联网作为第四次工业革命的基石,自其概念诞生以来,迅速吸引了工业界的广泛关注(美国通用电气公司,2012)。通过工业互联网的赋能,企业得以构建更为智能化和高效的生产管理架构,不仅可以显著降低生产成本,还提升了资源的利用效率和生产的整体效能(Li et al., 2017; 牛凯等, 2021)。万物互联是工业互联网建设的基石,越来越多的工业生产设备被接入网络,以实现生产过程的自动化和智能化。例如,通过引入温度、湿度等传感器来监控工业设备的运行状态,实现故障预警;或通过安装工业相机、摄像头等设备来

监控生产过程,进行产品质量检测等(牛凯等, 2021)。在工业互联网的框架下,这些设备实时生成数据,并将这些数据传输到云端进行分析,如图1所示。然而,随着接入网络的设备日益增多,现有的通信系统开始难以满足工业互联网海量数据实时传输的通信需求。因此,为了适应工业互联网的发展,迫切需要开发更高效的传输技术,以提升工业网络的通信性能,满足其不断增长的通信需求。这不仅关乎单一企业的生产力提升,更是关系整个工业互联网生态系统的健康发展。




图1 工业互联网的生产场景示例

Fig. 1 A production scenario for the industrial internet

语义通信技术,作为近来通信领域的研究热点,正逐渐展现出其革命性潜力。该技术依托于深度神经网络强大的理解能力,通过深度学习技术构建语义编解码器和语义知识库,并形成一套完整的语义通信系统(张平等,2023)。与传统通信方式相比,语义通信技术的一个显著优势在于其对通信过程中符号错误的容忍度,这使得它能够在一定程度上突破香农定律的限制,实现更高的通信性能。众多相关领域的研究工作已经充分证实了语义通信技术的强大性能和应用潜力(张平等, 2023; Gündüz et al., 2022)。基于此,本研究提出将语义通信技术应用于工业网络通信场景,旨在增强工业网络的通信性能。

鉴于图像信源已成为现代工业通信系统中的主要传输对象,本研究致力于设计一种适用于工业生产场景中图像信源传输的语义编码网络。为此,选取工业药品生产中的缺陷检测场景来验证所设计网络的性能。在药品生产过程中,由于机器操作误差或设备老化等因素,可能会出现药片缺失、药袋破损或污损等各种缺陷。这些有缺陷产品需要在生产过程中及时被检出并剔除,以确保产品的质量。现代缺陷检测主要通过各种缺陷检测算法自动化进行,相比人工检测更加高效和准确。而为了实现成本降低和集中管理,广泛采用的策略是在生产端部署图像采集设备,并将采集到的药品图像传输至云端进行集中检测。然而,

随着生产规模的扩大和生产速度的提升, 图像采集设备增多, 图像传输需求增加, 工业网络逐渐难以支撑海量产品图片的传输, 不得不牺牲图像质量以满足通信需求。然后, 图像质量的下降将直接影响缺陷检测的准确性。

因此, 本研究将基于语义编码技术的工业语义通信系统应用于图像传输系统, 以优化工业网络的通信性能, 增强工业传输网络对相关任务的支撑能力。首先, 介绍了两种面向工业互联网的语义通信技术。然后, 阐述了所设计的语义编码传输系统, 包括语义通信系统的架构设计, 构成系统的各个模块的深度神经网络结构, 以及整个模型的训练和调优方法。最后, 通过仿真验证系统性能, 并与传统通信方案进行了对比分析。研究成果为构建高性能的工业通信网络提供了新的思路, 在提升工业网络通信性能方面具有巨大潜力。

1 理论方法

工业互联网领域庞大的数据传输量和对实时性的高度要求为现有的工业通信网络带来了严峻的考验。随着深度学习等技术的飞速发展, 许多理论上更为高效地通信技术得以实现, 为工业通信网络的性能提升提供了新的解决方案。在本节中, 将深入探讨两种基于神经网络的前沿技术, 分别是面向工业网络的语义通信技术和深度信源信道联合编码技术。这两种适用于工业通信场景的技术, 是设计实现面向工业互联网的语义编码传输系统的重要理论基础。

1.1 面向工业网络的语义通信技术

在工业网络中, 通信系统的服务对象是各种工业机器及算法模型, 其最终目的则是保证各种下游任务的精准度。传统的面向人类视觉感知的图像传输任务中, 应保证尽可能无失真的重建图像, 即在像素层面上的高度还原。而在面向机器任务的通信中, 只需要保留图像中的关键特征, 就可以实现高精度地完成下游任务(Qin et al., 2021; Niu et al., 2022)。语义通信技术正是一种基于语义特征来压缩传输图片的方法。它采用语义特征驱动的编码策略, 强调在收发端准确传递信源的语义特征。语义通信的这一特性使得即使在通信资源受限或通信条件不理想的情况下, 也能够保留图像的关键特征, 从而保证下游任务的精准性。这与工业通信网络的需求高度契合(Shannon et al., 1971; Gündüz et al., 2008)。

香农奠定了通信理论的基础, 韦弗进一步将通信过程细分为三个层次: 符号的传输、语义信息的交换以及语用信息的交换(Yao et al., 2024)。在最基本的符号传输层面, 是实现信源符号的无差错传输。但经过数十年的发展, 该技术已经接近理论上的性能极限, 即香农极限。相对于传统通信, 语义通信更侧重于保持发送端和接收端之间语义信息的一致性。它放宽了对传输过程中比特错误的严格要求, 只需确保语义信息的准确传递, 而非比特序列的完全对应。这种容错特性为语义通信技术带来了超越香农极限的潜力, 并为多种通信难题提供了新的解决策略。

参照语义通信的理论(Shannon et al., 1971), 一个由语义层和传输层构成的面向工业网络的语义通信系统模型如图2所示。语义层由语义编码器、语义解码器以及工业背景知识库3个部分组成。语义编码器从信源中提取语义特征并编码表示, 语义解码器负责将接收到的语义特征表示解析并还原为人类或工业生产机器可理解的形式。工业背景知识库在此过程中起关键作用, 它为编解码器提供必要的先验知识, 确保编码和解码过程中语义信息的一致性。传输层负责将语义表示的数据比特通过传统通信系统传输。

1.2 深度信源信道联合编码技术

信源编码与信道编码是两个独立分离的模块, 如图3(a)所示, 这种分离式的设计降低了通信系统的设计、实现难度, 并已达到最优的性能。但是, 这种分离式系统是针对某一特定的信道条件优化设计的, 当信道条件发生变化时, 系统的性能将会受到严重影响。一方面, 当信道条件变差时, 符号错误的概率迅速增加, 导致接收端大概率无法接收到正确的信道码字以及重建的信源严重失真。另一方面, 当信道条件优于预设信道条件时, 由于各部分的码率已经固定, 分离式的编码也无法从更优的信道条件中拿到额外的传输增益, 这一特性也被称为“悬崖效应”(Bourtsoulatze et al., 2019)。而信源信道联合编码则可以克服这一问题, 如图3(b)所示, 在采用信源信道联合编码的系统中, 信源数据在输入信源信道联合编码器后直接转化为可以在信道中传输的符号, 这一联合编码的方式可以克服“悬崖效应”, 减少信息的无效传输带来的资源浪费, 在多变的信道条件中达到更优的压缩传输性能。

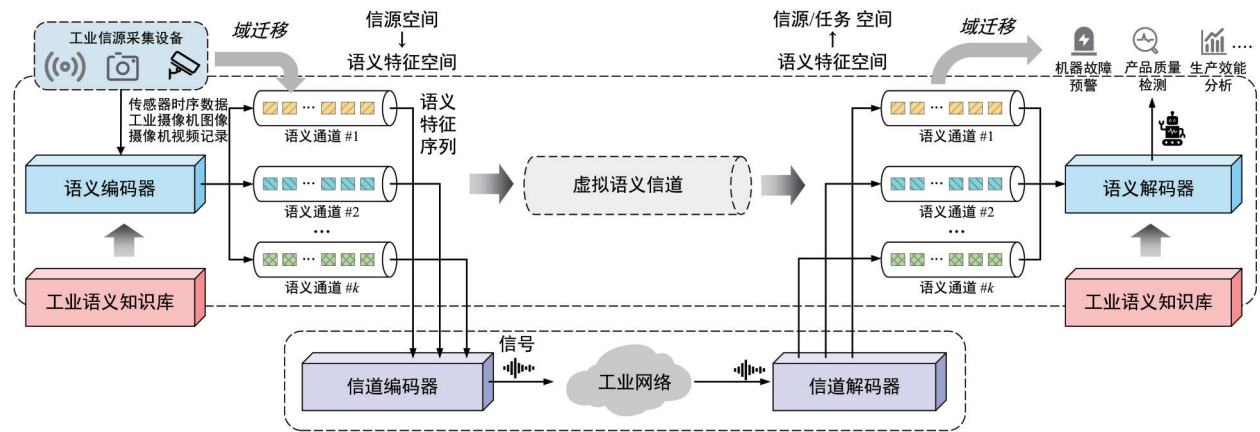


图2 工业语义通信系统基本模型

Fig. 2 Basic model of industrial semantic communication systems

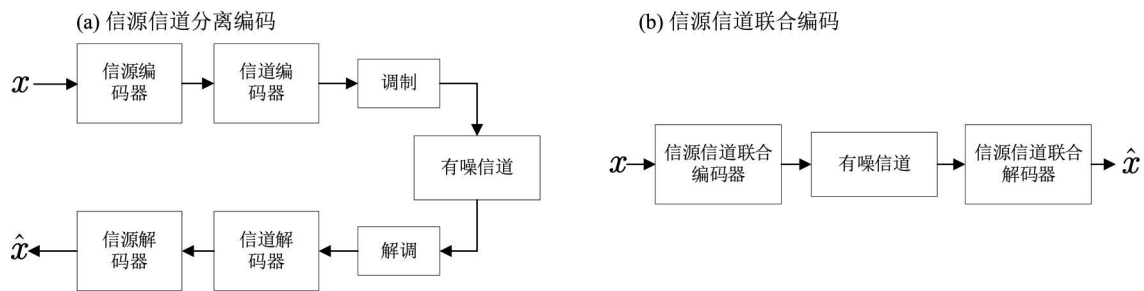


图3 信源信道分离编码和信源信道联合编码

Fig. 3 Source-channel separation coding and source-channel co-coding

文献(Ballé et al., 2020)提出了用深度神经网络作为信源信道联合编码的编解码器，通过深度神经网络直接将像素值映射为可以直接在通信信道上传输的符号，即将深度神经网络的输出作为信源信道联合编码后的符号在无线信道中进行传输，相关实验已经证明了这一方法可以解决悬崖效应的问题，并在信道条件较差时达到优于传统方案的图像重建效果。本文设计的面向工业互联网的语义编码系统将上述两种技术结合，能够充分解决工业通信高数据传输量和实时性要求高的问题。

2 语义编码传输系统设计

本研究所提出的面向工业网络的语义编码传输系统基于语义通信及深度信源信道联合编码的设计思想，并采用先进的深度神经网络架构，设计了拥有语义特征提取，信源信道联合编码以及可变长编码能力的高性能语义编解传输系统，显著提高了工业网络中的数据压缩传输效率。下面介绍该语义编码传输系统的整体架构、模型各个

模块的深度神经网络结构，以及模型的训练与调优方法。

2.1 系统的架构

如图4所示，该系统主要由非线性变换编解码器，深度信源信道联合编解码器，先验编解码器及熵模型模块组成。对于一个需要传输的工业产品图像 x ， x 首先被输入到一个非线性变换编码器中进行非线性变换，该变换可以将 x 映射到语义隐空间中，转化为语义隐空间中的表征矢量 y ，即提取出的工业语义特征。此后矢量 y 被送入深度信源信道联合编解码器中，转换为可以直接在无线信道中传输的符号并发送到接收端。接收端接收到这些符号后，通过深度信源信道联合解码器重建出矢量 \hat{y} ，然后在非线性变换解码器将语义表征矢量映射回原图像空间，得到重建的工业产品图像 \hat{x} 。

需要说明的是，在最初的深度信源信道联合编码方法中，所设计的编码器采用定长编码的方式，即输入图像最终映射成的符号的维度是相同的。然而，定长编码的方式并不能达到最优的压

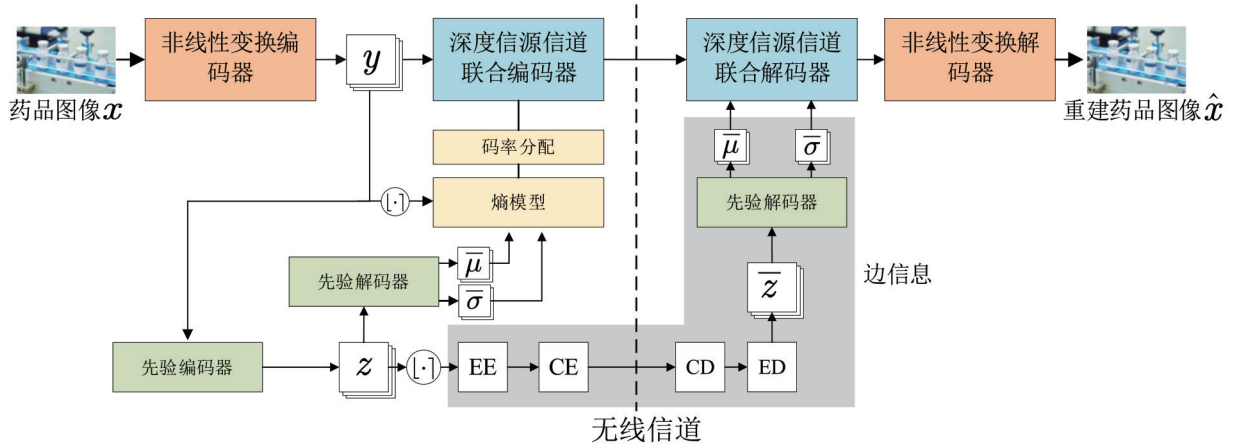


图4 工业语义编码传输系统的整体架构

Fig. 4 The overall architecture of the industrial semantic coding transmission system

缩传输性能。本研究采用了变长编码的方式(Liu et al., 2021; Dai et al., 2022), 在采用神经网络对矢量 y 进行信源信道联合编码时, 会通过一个熵模型对矢量 y 中的各个元素进行概率估计, 评估出各个元素信息量多少, 再用估计出的概率指导信源信道联合编码过程, 即用维度较高的符号来表示信息量较多的元素、用维度较低的符号来表示信息量较少的元素。

在上述过程中, 熵模型对工业语义信息的概率估计的精准性将直接决定整个系统的性能。相关研究表明, 非线性变换编码可以更好地解开各个维度之间的相关性, 进而实现更为精准的概率建模(Dai et al., 2022)。所以, 本研究不直接对输入图像 x 进行信源信道联合编码, 而是先通过非线性变换编码将其映射到语义空间, 提取出各维度间相对独立的工业语义特征, 再进行熵估计和编码等过程。同时, 参照文献(Dai et al., 2022)中的工作, 模型还引入了先验编码器来提取矢量 y 中的先验信息, 以实现更为精确的概率估计。提取出的先验信息也会作为边信息传输到接收端, 用以指导接收端深度信源信道联合解码器的解码过程。该边信息数据量很小, 故采用传统的数字编码通信方式对边信息进行传输。图4中的EE(entropy encoder)/ED(entropy decoder)表示熵编/解码器, CE(channel encoder)/CD(channel decoder)表示信道编/解码器。

2.2 各模块的神经网络结构

非线性变换编码器采用了 Swin transformer 的

网络结构(Vaswani et al., 2017), 如图5所示。输入图像先被分割为不重合的图像块, 每个图像块的大小为 $2 \times 2 \times 3$ 。然后, 对这些图像块做线性嵌入, 从而转化为可以输入到Transformer模块中的“token”(Ballé et al., 2018), 并送入到Transformer模块中进行处理。Transformer模块的结构在图5中给出, 其中MHSA为多头注意力模块(Ballé et al., 2018)。此后, Transformer块输出的“token”被送入到块合并网络中, 块合并网络为一个简单的全连接网络, 其作用是将相邻的块或token合并为一个块, 实现对图像的降维操作。重复上述处理过程, 最后的输出即为前文提到的工业语义特征 y , 而 y 中的元素则为网络输出中的每一个token。非线性变换解码器则为相对应的反向映射过程, 不再赘述。

图4中的熵模型与先验编解码器均基于最基本的卷积神经网络, 对其可以实现概率建模与概率估计(Minnen et al., 2018; Deng et al., 2009)。信源信道联合编解码器的结构, 如图6所示。对于非线性变换编码器输出的矢量 y , 熵模型会估计出矢量 y 中各个元素的概率分布, 由此计算出每个元素的信息量, 并根据信息量的大小进行码率分配。信源信道联合编码器则会根据分配好的码率将 y 中的token转化为维度大小不同的符号, 然后通过无线信道传输到接收端。在接收端的信源信道联合解码器则会在接收到的边信息的指导下对接收到的符号进行解码, 重建出工业语义特征 \hat{y} , 并交给非线性变换解码器进行处理。

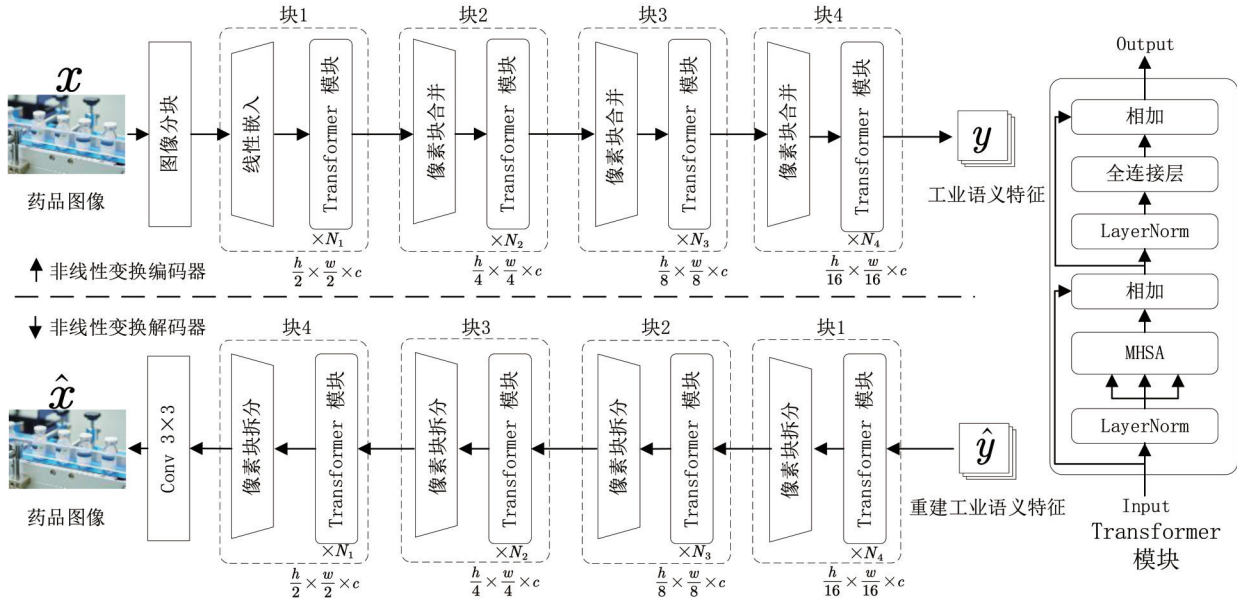


图 5 非线性变换编解码器的网络结构

Fig. 5 Network structure of a nonlinear transformation codec

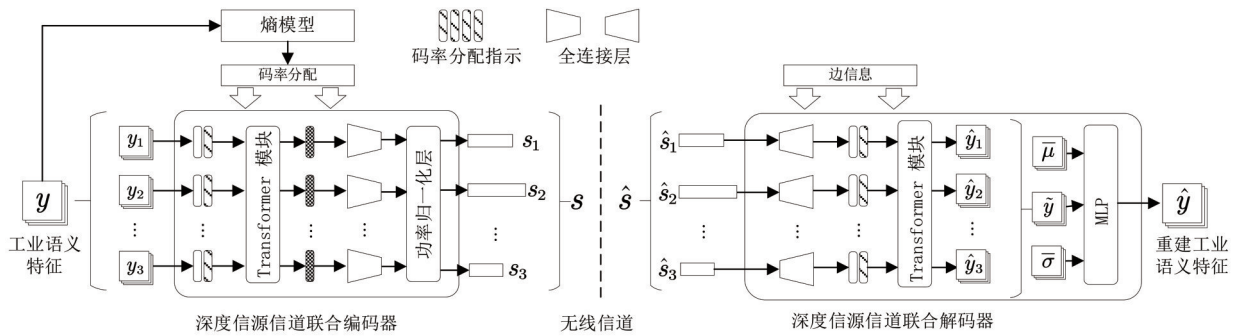


图 6 深度信源信道联合编解码器的网络结构

Fig. 6 The network structure of the deep source-channel joint codec

2.3 模型训练与调优

为了使模型在保持较高的图像重建质量的同时拥有尽可能高的压缩效率, 将训练网络的损失函数设置为

$$L = \mathbb{E}_{x \sim p_s(x)} \left[\lambda (-\eta \log P_{\bar{y}|\bar{z}}(\bar{y}|\bar{z}) - \frac{1}{C} \log P_{\bar{z}}(\bar{z})) + d(x, \hat{x}) \right],$$

其中 $-\eta \log P_{\bar{y}|\bar{z}}(\bar{y}|\bar{z})$ 表示语义隐空间中表征矢量 y 转化成在信道中的传输符号时对应的符号数, η 为信息量到符号维度的比例因子, $\log P_{\bar{z}}(\bar{z})/C$ 表示边信息转化成在信道中传输的符号时对应的符号数。因为边信息采用的是数字编码, 故用常量 C 表示边信息的信息量到信道符号数的比例关系, λ 为拉格朗日乘子, 在损失函数中调节码率与图像重建质量, $d(x, \hat{x})$ 表示原图像与重建图像之间的失真度量。在训练时, 采用均方误差作为原图像与重建

图像之间的失真度量, 即

$$d(x, \hat{x}) = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2.$$

3 部署验证

为了验证所提出的语义编码传输系统在工业网络中的表现, 在实际的工业药品缺陷检测场景中对系统进行了部署与验证。本节将介绍验证的流程以及验证结果。

3.1 验证场景及参数配置

语义编码传输系统的验证在实际的药品生产场景中进行。整个工业药品缺陷检测系统的运行流程, 如图 7 所示。其中, 工业药品生产端由药品传送带及部署在药品传送带上的工业相机组成, 工业生产端的设备及药品实物如图 8 所示。药品在

传送带上传输时, 位于传送带上的工业相机会捕捉流水线上的药品图像, 并由语义通信网络对捕捉到的药品图像进行编码并传输到云端的服务器中, 然后由布署在服务器上的缺陷检测算法对药

品图像进行缺陷检测。本研究还设计了交互展示界面, 用于对整个验证流程进行监控以及展示各项数据结果。




图7 验证系统的工作流程

Fig. 7 The workflow of validate system

在实现时, 为了降低仿真工业生产场景的成本, 语义通信网络的推理过程基于单个 GTX 3060 显卡进行。语义编码传输系统的传输信噪比设置为 10 dB, 这一信噪比符合工业场景中的实际需求。在数据集方面, 采用 ImageNet (Ryan, 2004)、Kodak 以及药品生产过程中采集到的药品图片作为训练数据集, 数据集总量约为一万张。测试时, 则以实际的药品图像为测试数据。为了测试所提出系统的泛用性, 用多种不同分辨率的药品图像进行测试, 每种分辨率的图片约 1 000 张。选择当前工业网络中常用的“H.264 + LDPC”方法(即工业网络传统通信方法 1)以及“H.265 + LDPC”方法(即工业网络传统通信方法 2)作为比较基准 (Wiegand et al., 2003; P'ng et al., 2019)。

标准。其中, 峰值信噪比反映了重建图像在像素值层面上与原图像的相似度, 结构相似度度量指标则反应了重建图像与原图像在图像结构上的相似性。考虑到所用方法为信源信道联合编码, 以信道带宽比 (CBR, channel bandwidth ratio) 作为图像压缩率的度量指标。CBR 表示信源在信道中传输时的符号数与信源原本的符号数的比值。CBR = k/m , 其中 k 为原图像经过信源信道联合编码后输出的符号数, m 为原图像的像素数。

选取 256×256、512×512、1 024×1 024 三种分辨率的图像各 1 000 张作为测试图像。如图 9 所示, 无论是以 PSNR 还是 SSIM 作为衡量指标, 所设计的语义编码传输系统的图像重建质量均优于两种工业网络传统通信方法。具体来说:




图8 工业生产端的设备及药品实物图

Fig. 8 Equipment and drugs at the industrial production end

3.2 压缩传输性能对比

与两种工业传统通信方法的对比结果, 如图 9~10 所示。为了衡量在达到相同压缩率时的图像重建质量, 以峰值信噪比 (PSNR, peak signal-to-noise ratio) 和结构相似度度量指标 (SSIM, structure similarity index measure) 作为衡量图像质量的

(1) 在图像分辨率为 256×256 时, 相比于工业网络传统通信方法 1, 采用语义通信方法得到的重建图像的 PSNR 值提高了约 4 dB, SSIM 值提高了约 0.15; 且在 CBR 较低时两者性能差距较大, PSNR 值相差约 5 dB, SSIM 值相差约 0.2。相比于工业网络传统通信方法 2, 采用语义通信方法得到的重建图像的 PSNR 值提高了约 2 dB, SSIM 值提高了约 0.05。

(2) 在图像分辨率为 512×512 时, 相比于工业网络传统通信方法 1, 采用语义通信方法得到的重建图像的 PSNR 值提高了约 3 dB, SSIM 值提高了约 0.07; 且在 CBR 较低时两者的 SSIM 值有较大差距, 相差约 0.1。相比于工业网络传统通信方法 2, 采用语义通信方法得到的重建图像的 PSNR 值提高了约 1.5 dB, SSIM 值提高了约 0.05。

(3) 在图像分辨率为 $1\ 024 \times 1\ 024$ 时, 相比于工业网络传统通信方法 1, 采用语义通信方法得到的重建图像的 PSNR 值提高了约 3 dB, SSIM 值提高了约 0.1; 且在 CBR 较高时两者的 PSNR 值有较大差距, 相差约 3.5 dB。相比于工业网络传统通信方法 2, 采用语义通信方法得到的重建图像的 PSNR 值提高了约 1.5 dB, SSIM 值提高了约 0.05。

上述结果表明, 对不同的分辨率的图片, 所提出的语义编码传输方法均可达到优于传统方案的图像传输性能。在压缩率相同即占用的带宽相同时, 语义编码传输方法可以重建出更高质量的

图片, 能够更好的为各项下游任务提供支持。

在工业产品瑕疵检测场景中, 通信系统除了需要具备强大的图像压缩编码与重建能力外, 还应当具有较快的图像传输速度, 以匹配工业生产场景中的实时性需求。3 种分辨率图像的平均传输处理时间, 如图 11 所示。可以看到, 相较于处理速度较快的工业网络传统通信方法 1, 所设计的语义通信方法在 3 种分辨率的图像上均有 50% 以上的速率提升。相较于传输处理速度较慢的工业网络传统通信方法 2, 则达到了几十倍的传输速率提升。




图 9 图像的重建质量对比(PSNR)

Fig. 9 Comparison of the reconstruction quality of images(PSNR)




图 10 图像的重建质量对比(SSIM)

Fig. 10 Comparison of the reconstruction quality of images(SSIM)




图 11 传输处理速度对比

Fig. 11 Comparison of transfer processing speeds

3.3 下游任务性能对比

工业场景中的数据传输最终是为了完成工业生产场景中的下游任务, 故下游任务的准确率也是衡量传输系统适用性的重要指标。为了测试工业语义编码传输系统对下游任务的影响, 选择 500 个药品进行上机测试, 其中包含约 100 个损坏药品。衡量检测准确率的标准为 F1-score 指标, 测试结果如图 12 所示。从图中可以看出, 对于每一类

缺陷及所有缺陷, 采用语义通信方法后的检测准确率与基于原图的检测准确率基本没有差异, 充分说明本研究的方法在拥有强大的图像压缩传输能力的同时, 不会对工业网络中下游任务的性能造成影响。图 13 为实际药品的图像重建与缺陷检测结果。从图 13 可以发现, 药品的重建图像的清晰度较高, 且在重建图像上的缺陷检测结果与在原图上的缺陷检测结果基本一致。




图 12 下游任务准确率对比

Fig.12 Comparison of the accuracy of downstream tasks




图 13 实际药品的图像重建和缺陷检测结果

Fig. 13 Image reconstruction and defect detection results of the actual drug product

4 总结

针对工业互联网中日益增长的数据传输需求, 提出了一种面向工业网络的语义编码传输系统, 旨在提高工业通信网络的数据压缩与传输的性能。在实际的药品工业生产和药品缺陷检测场景, 对所提出的语义编码传输系统进行了测试。结果表明, 与传统通信方法相比, 所设计的语义通信系

统在图像重建质量、传输处理速度以及下游任务性能方面均展现出显著优势。总体来说, 该系统在达到相同压缩率时, 图像重建质量(以 PSNR 和 SSIM 为衡量标准)优于传统方案, 同时传输处理速度提高了 50% 以上, 且对下游任务的准确率没有负面影响。可以看出, 语义通信技术在工业互联网中具有广阔的应用前景, 有望推动工业互联网的发展, 并为通信技术进步开辟新的路径。

参考文献:

- 牛凯,戴金晟,张平,等,2021.面向6G的语义通信[J].移动通信,45(4):85-90.
- 美国通用电气公司,2012.工业互联网:突破智慧和机器的界限[R].美国通用电气公司.
- 张平,牛凯,姚圣时,等,2023.面向未来的语义通信:基本原理与实现方法[J].通信学报,44(5):1-14.
- BALLÉ J, CHOU P A, MINNEN D, et al, 2020. Nonlinear transform coding[J]. IEEE J Top Signal Process, 15(2): 339-353.
- BALLÉ J, MINNEN D C, SINGH S, et al, 2018. Variational image compression with a scale hyperprior [EB/OL]. [2018-03-01].<https://doi.org/10.48550/arXiv.1802.01436>.
- BOURTSOULATZE E, KURKA D B, GÜNDÜZ D, 2019. Deep joint source-channel coding for wireless image transmission [J]. IEEE Trans Cogn Commun Netw, 5(3): 567-579.
- DAI J, WANG S, TAN K, et al, 2022. Nonlinear transform source-channel coding for semantic communications [J]. IEEE J Sel Areas Commun, 40(8): 2300-2316.
- DENG J, DONG W, SOCHER R, et al, 2009. Imagenet: A large-scale hierarchical image database [C]//IEEE Conference on Computer Vision and Pattern Recognition. Miami, FL, USA:IEEE Computer Society: 248-255.
- GÜNDÜZ D, ERKIP E, 2008. Joint source-channel codes for MIMO block-fading channels [J]. IEEE Trans Inf Theory, 54(1): 116-134.
- GÜNDÜZ D, QIN Z, AGUERRI I E, et al, 2022. Beyond transmitting bits: Context, semantics, and task-oriented communications [J]. IEEE J Sel Areas Commun, 41(1): 5-41.
- LI J Q, YU F R, DENG G, et al, 2017. Industrial internet: A survey on the enabling technologies, applications, and challenges [J]. IEEE Commun Surv Tutor, 19(3): 1504-1526.
- LIU Z, LIN Y, CAO Y, et al, 2021. Swin transformer: Hierarchical vision transformer using shifted windows [C]// IEEE/CVF International Conference on Computer Vision. Montreal, QC, Canada: IEEE Computer Society: 10012-10022.
- MINNEN D, BALLÉ J, TODERICI G, 2018. Joint autoregressive and hierarchical priors for learned image compression [EB/OL]. Advances in Neural Information Processing Systems. [2018-09-08]. <https://doi.org/10.48550/arXiv.1809.02736>.
- NIU K, DAI J, YAO S, et al, 2022. A paradigm shift toward semantic communications [J]. IEEE Commun Mag, 60(11): 113-119.
- P' NG C, GREEN J, CHONG L C, et al, 2019. BPG: Seamless, automated and interactive visualization of scientific data [J]. BMC Bioinformatics, 20(1): 42.
- QIN Z, TAO X, LU J, et al, 2021. Semantic communications: Principles and challenges [EB/OL]. [2022-06-27]. <https://doi.org/10.48550/arXiv.2201.01389>.
- RYAN W E, 2004. An introduction to LDPC codes [R]. Coding and Signal Processing for Magnetic Systems 5.2. CRC Press: 1-23.
- SHANNON C E, WEAVER W, 1971. The mathematical theory of communication [M]. The University of Illinois Press.
- VASWANI A, SHAZEER N, PARMAR N, et al, 2017. Attention is all you need [EB/OL]. Advances in Neural Information Processing Systems. [2017-12-06]. <https://doi.org/10.48550/arXiv.1706.03762>.
- WIEGAND T, SULLIVAN G J, BJONTEGAARD G, et al, 2003. Overview of the H. 264/AVC video coding standard [J]. IEEE Trans Circuits Syst Video Technol, 13(7): 560-576.
- YAO S, LU Y, NIU K, et al, 2024. Semantic information processing for interoperability in the industrial internet of things [J]. Fundam Res, 4(1): 8-12.

(责任编辑 王海蓉)